

Modelovanie volatility - ARCH a GARCH modely

Beáta Stehlíková
Časové rady, FMFI UK

Ceny akcií


- Týždenné ceny akcií (knížnica `quantmod` z cvičení)
- Vypočítame spojité výnosy:

```
1 library(quantmod)
2 library(astsa)
3
4 getSymbols("EBAY", from="2010-01-01", to="2014-12-31", auto.assign=TRUE)
5 EBAY <- to.weekly(EBAY)
6 vynosy <- diff(log(EBAY$EBAY.Adjusted))[-1] # vynechame NA na zaciatku
7
8 chartSeries(vynosy, theme="white")
```

- Na cvičení na začiatku semestra sme analyzovali autokorelácie takýchto dát

Výnosy

- Priebeh výnosov:



Výnosy akcií: Black-Scholesov model

- Black-Scholesov model (\rightarrow finančná mat., PDR):

$$dS = \mu S dt + \sigma S dw,$$

kde w je Wienerov proces.

- Existuje explicitné vyjadrenie pre cenu akcie v čase t :

$$S_t = S_0 e^{(\mu - 1/2 \sigma^2)t + \sigma w_t}$$

- Výnosy v Black-Scholesovom modeli:

$$vynost_t = \ln \left(\frac{S_t}{S_{t+\Delta t}} \right) = (\mu - 1/2 \sigma^2) \Delta t + \sigma \Delta w$$

\Rightarrow nezávislé s rozdelením $N((\mu - 1/2 \sigma^2) \Delta t, \sigma^2 \Delta t)$


- Model pre časový rad výnosov:

$$vynost_t = c + u_t,$$

kde u je biely šum

Výnosy akcií: naše dáta

- Podľa ACF by to mohol byť biely šum



Výnosy akcií: naše dáta

- Výnosy modelujeme bielym šumom:

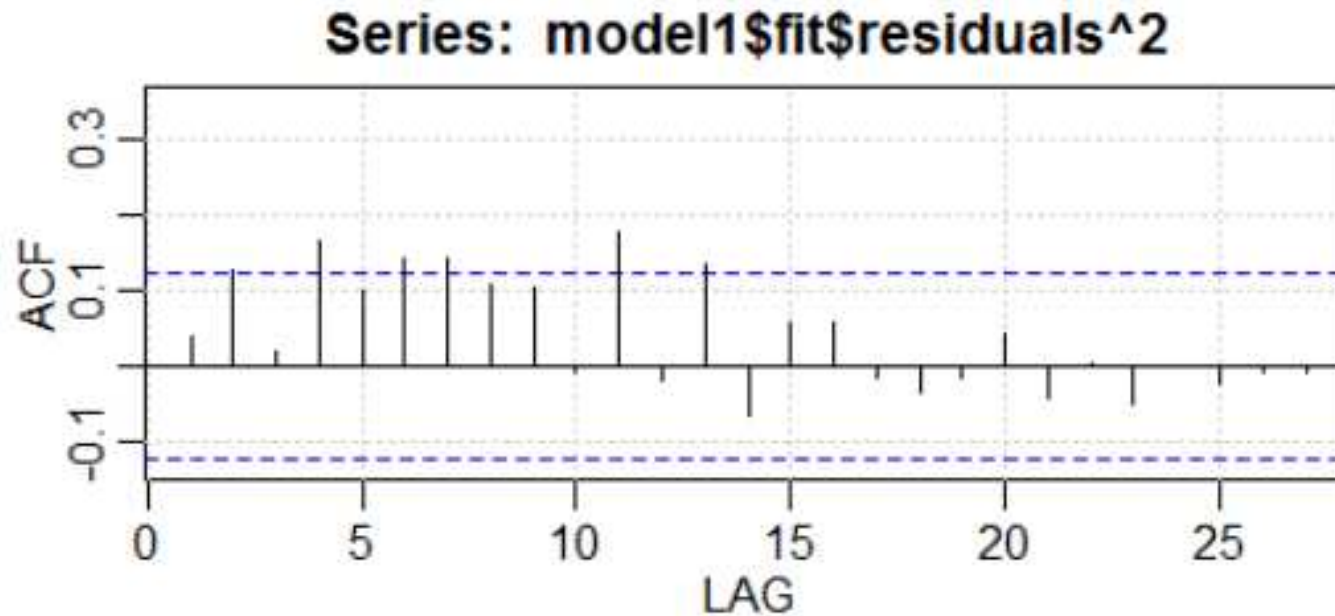
```
12 model1<-sarima(vynosy,0,0,0, details=FALSE)
13 acf2(model1$fit$residuals) # to iste ako acf2(vynosy) -> ok
14 acf2(model1$fit$residuals^2) # -> PROBLEM
```

→ rezíduá sú výnosy posunuté o konštantu

- Ak je absolútna hodnota rezídua malá, tak väčšinou nasleduje rezíduum tiež s malou absolútnou hodnotou
- Podobne za rezíduom s veľkou absolútnou hodnotou nasleduje často rezíduum s veľkou absolútnou hodnotou - môže byť kladné aj záporné, preto sa táto vlastnosť na autokorelácii neprejavila
- **Druhé mocniny budú zrejme korelované** (pre biely šum to ale neplatí)

Výnosy akcií: naše dáta

- Autokorelácia **druhých mocnín:**




→ **signifikantná autokorelácia**

- **OTÁZKA:**
Aký model dokáže zachytiť takéto vlastnosti?

Výnosy akcií: naše dáta

- Možné vysvetlenie: **nekonštatná disperzia**



ARCH a GARCH modely

- u nie je biely šum, ale

$$u_t = \sqrt{\sigma_t^2} \eta_t,$$

kde η je biely šum s jednotkovou disperziou; teda

$$u_t \sim N(0, \sigma_t^2)$$

- **ARCH model** (autoregressive conditional heteroskedasticity) - rovnica pre disperziu σ_t^2 :

$$\sigma_t^2 = \omega + \alpha_1 u_{t-1}^2 + \dots + \alpha_p u_{t-p}^2$$

- **Ohraničenia na parametre:**

- ◇ na zabezpečenie kladnosti disperzie:

$$\omega > 0, \alpha_1, \dots, \alpha_{p-1} \geq 0, \alpha_p > 0$$

- ◇ kvôli stacionarite:

$$\alpha_1 + \dots + \alpha_p < 1$$

ARCH a GARCH modely

- Nevýhody ARCH modelov:
 - ◇ malý počet členov u_{t-i}^2 často nestačí - vo štvorcoch rezíduí je stále autokorelácia
 - ◇ pri väčšom počte členov sú koeficienty často nesignifikantné alebo nespĺňajú uvedené ohraničenia na parametre
- Zovšeobecnenie: **GARCH modely** - odstraňujú tieto problémy

ARCH a GARCH modely

- **GARCH model** (generalized autoregressive conditional heteroskedasticity) rovnica pre disperziu σ_t^2 :

$$\begin{aligned}\sigma_t^2 &= \omega + \alpha_1 u_{t-1}^2 + \dots + \alpha_p u_{t-p}^2 \\ &\quad + \beta_1 \sigma_{t-1}^2 + \dots + \beta_q \sigma_{t-q}^2\end{aligned}$$

- **Ohraničenia na parametre:**
 - ◇ na zabezpečenie kladnosti disperzie:

$$\omega > 0, \alpha_1, \dots, \alpha_{p-1} \geq 0, \alpha_p > 0$$

$$\beta_1, \dots, \beta_{q-1} \geq 0, \beta_q > 0$$

- ◇ kvôli stacionarite:

$$(\alpha_1 + \dots + \alpha_p) + (\beta_1 + \dots + \beta_q) < 1$$

- Často sa používa GARCH(1,1).

GARCH modely v R-ku

- Modelovanie výnosov YHOO - pokračovanie
- V R-ku:
 - ◇ knižnica `fGarch`
 - ◇ funkcia `garchFit`, model sa píše v tvare napr.
`arma(1,1)+garch(1,1)`
 - ◇ parametrom `trace=FALSE` zrušíme vypisovanie podrobností ohľadom konvergenencie optimalizačného procesu
- Odhadujeme model **konštanta + šum**; na modelovanie šumu skúsime **ARCH/GARCH modely**

ARCH(1)

- Odhadovanie ARCH(1) modelu:

```
16 # arch(1) = garch(1,0)
17 model10 <- garchFit(~garch(1,0), data=vynosy, trace=FALSE)
18 stand.rez <- model10@residuals/model10@sigma.t # standardizovane rezidua
19 acf2(stand.rez)
20 acf2(stand.rez^2)
21 summary(model10)
```

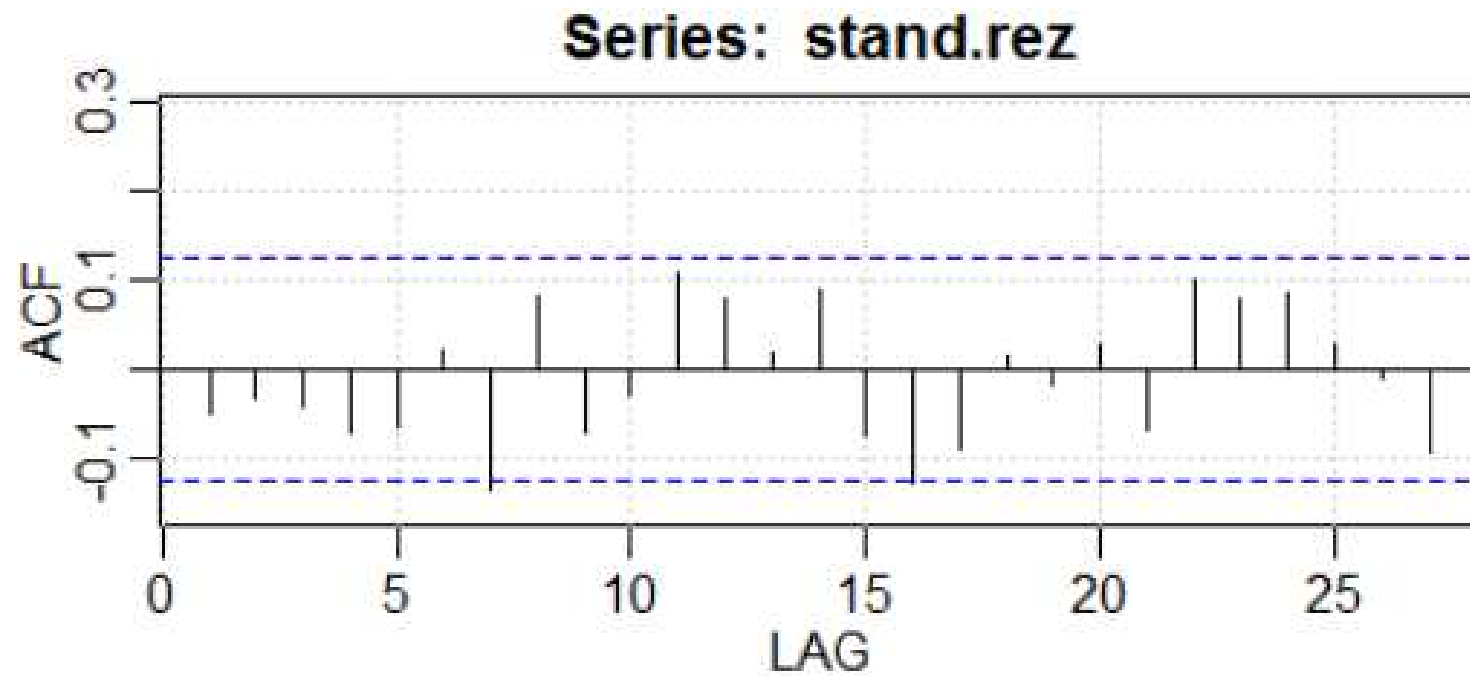
- Zobrazíme teda:
 1. ACF štandardizovaných rezíduí
 2. ACF štandardizovaných druhých mocnín rezíduí
 3. `summary` s testami o štandardizovaných rezíduách a ich druhých mocninách

GARCH modely v R-ku

- Prístup k užitočným hodnotám:
 - ◇ `@fitted` - fitované hodnoty
 - ◇ `@residuals` - rezíduá
 - ◇ `@h.t` - odhadnutá variancia
 - ◇ `@sigma.t` - odhadnutá štandardná odchýlka
- Štandardizované rezíduá - rezíduá vydelené ich štandardnou odchýlkou - majú byť bielym šumom
- Takisto ich druhé mocniny majú byť bielym šumom


ARCH(1)

- Rezíduá:



ARCH(1)

- Druhé mocniny:



Testovanie rezíduí

- Testy:

Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	29.18907	4.588523e-07
Shapiro-Wilk Test	R	W	0.9821336	0.002392983
Ljung-Box Test	R	Q(10)	12.29485	0.2658079
Ljung-Box Test	R	Q(15)	21.08263	0.1342099
Ljung-Box Test	R	Q(20)	28.34245	0.1015375
Ljung-Box Test	R ²	Q(10)	27.55866	0.002123322
Ljung-Box Test	R ²	Q(15)	44.23218	0.0001011277
Ljung-Box Test	R ²	Q(20)	46.02944	0.0007985573
LM Arch Test	R	TR ²	25.98164	0.01079828

- Je tu: testovanie normality, Ljung-Box pre štandardizované rezíduá a ich druhé mocniny
- Čo je nové: testovanie homoskedasticity v týchto rezíduách

ARCH(2)

- Skúsime ARCH(2) - výsledky testov:

Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	34.65834	2.978778e-08
Shapiro-Wilk Test	R	W	0.9814854	0.001841151
Ljung-Box Test	R	Q(10)	10.75724	0.3767411
Ljung-Box Test	R	Q(15)	19.54396	0.1901334
Ljung-Box Test	R	Q(20)	26.93409	0.1371285
Ljung-Box Test	R ²	Q(10)	14.11704	0.1677196
Ljung-Box Test	R ²	Q(15)	27.9337	0.02198778
Ljung-Box Test	R ²	Q(20)	30.13048	0.06776678
LM Arch Test	R	TR ²	20.09535	0.06530357

ARCH(3)

- ARCH(3) - výsledky testov:

Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	33.88186	4.391851e-08
Shapiro-Wilk Test	R	W	0.9816512	0.001968254
Ljung-Box Test	R	Q(10)	10.70552	0.3809165
Ljung-Box Test	R	Q(15)	19.44674	0.1941989
Ljung-Box Test	R	Q(20)	26.77638	0.1416733
Ljung-Box Test	R ²	Q(10)	14.01256	0.1724194
Ljung-Box Test	R ²	Q(15)	27.74511	0.02322011
Ljung-Box Test	R ²	Q(20)	29.97015	0.07033882
LM Arch Test	R	TR ²	20.00903	0.06691536

ARCH(4)

- ARCH(4) - výsledky testov:


Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	12.79082	0.001669201
Shapiro-Wilk Test	R	W	0.9880808	0.0302226
Ljung-Box Test	R	Q(10)	10.54746	0.3938435
Ljung-Box Test	R	Q(15)	18.98255	0.2145258
Ljung-Box Test	R	Q(20)	26.02379	0.1650277
Ljung-Box Test	R ²	Q(10)	14.41393	0.1549343
Ljung-Box Test	R ²	Q(15)	21.97894	0.1083574
Ljung-Box Test	R ²	Q(20)	23.88737	0.2473466
LM Arch Test	R	TR ²	18.14053	0.1114896

- V rezíduách ani ich druhých mocninách už nie je autokorelácia.

ARCH(4)

- ACF druhých mocnín:



→ bez signifikantnej autokorelácie

ARCH(4)

- Ale ARCH koeficienty α_i nie sú signifikantné:

Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)	
mu	4.022e-03	2.433e-03	1.653	0.0983	.
omega	1.170e-03	2.003e-04	5.842	5.16e-09	***
alpha1	3.839e-02	1.250e-01	0.307	0.7587	
alpha2	1.259e-01	8.058e-02	1.563	0.1181	
alpha3	1.000e-08	1.475e-01	0.000	1.0000	
alpha4	1.098e-01	8.052e-02	1.364	0.1726	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

GARCH(1,1)

- Skúsme GARCH(1,1):

```
44 # garch(1,1)
45 model11 <- garchFit(~garch(1,1), data=vynosy, trace=FALSE)
46 stand.rez <- model11@residuals/model11@sigma.t # standardizovane rezidua
47 acf2(stand.rez)
48 acf2(stand.rez^2)
49 summary(model11)
50
```

- Testy:

Standardised Residuals Tests:

			Statistic	p-Value
Jarque-Bera Test	R	Chi ²	11.47005	0.003230806
Shapiro-Wilk Test	R	W	0.987312	0.02152423
Ljung-Box Test	R	Q(10)	10.26988	0.4171434
Ljung-Box Test	R	Q(15)	17.86043	0.2700744
Ljung-Box Test	R	Q(20)	23.83093	0.2498554
Ljung-Box Test	R ²	Q(10)	9.549341	0.4808792
Ljung-Box Test	R ²	Q(15)	17.0167	0.3178669
Ljung-Box Test	R ²	Q(20)	19.01346	0.5209512
LM Arch Test	R	TR ²	12.16882	0.4322184

GARCH(1,1)

- Odhadnuté koeficienty:


Error Analysis:

	Estimate	Std. Error	t value	Pr(> t)
mu	3.262e-03	2.351e-03	1.388	0.1652
omega	2.428e-05	3.596e-05	0.675	0.4994
alpha1	4.334e-02	2.401e-02	1.805	0.0711 .
beta1	9.396e-01	3.923e-02	23.954	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Odhadnutá štandardná odchýlka

- Vieme ju získať pomocou `@sigma.t` :



Odhadnutá štandardná odchýlka

- Iný prístup k niektorým grafom - `plot(model11)`:

```
> plot(model11)
```


```
Make a plot selection (or 0 to exit):
```

```
1: Time Series
2: Conditional SD
3: Series with 2 Conditional SD Superimposed
4: ACF of Observations
5: ACF of Squared Observations
6: Cross Correlation
7: Residuals
8: Conditional SDs
9: Standardized Residuals
10: ACF of Standardized Residuals
11: ACF of Squared Standardized Residuals
12: Cross Correlation between  $r^2$  and  $r$ 
13: QQ-Plot of Standardized Residuals
```

```
Selection: |
```


Predikcie

- Predikcie pomocou funkcie `predict`; parameter `n.ahead` určuje počet periód




Predikcie

- Parameterom nx vieme zmeniť počet periód z dát, ktoré sa vykreslia (teraz $nx=100$):



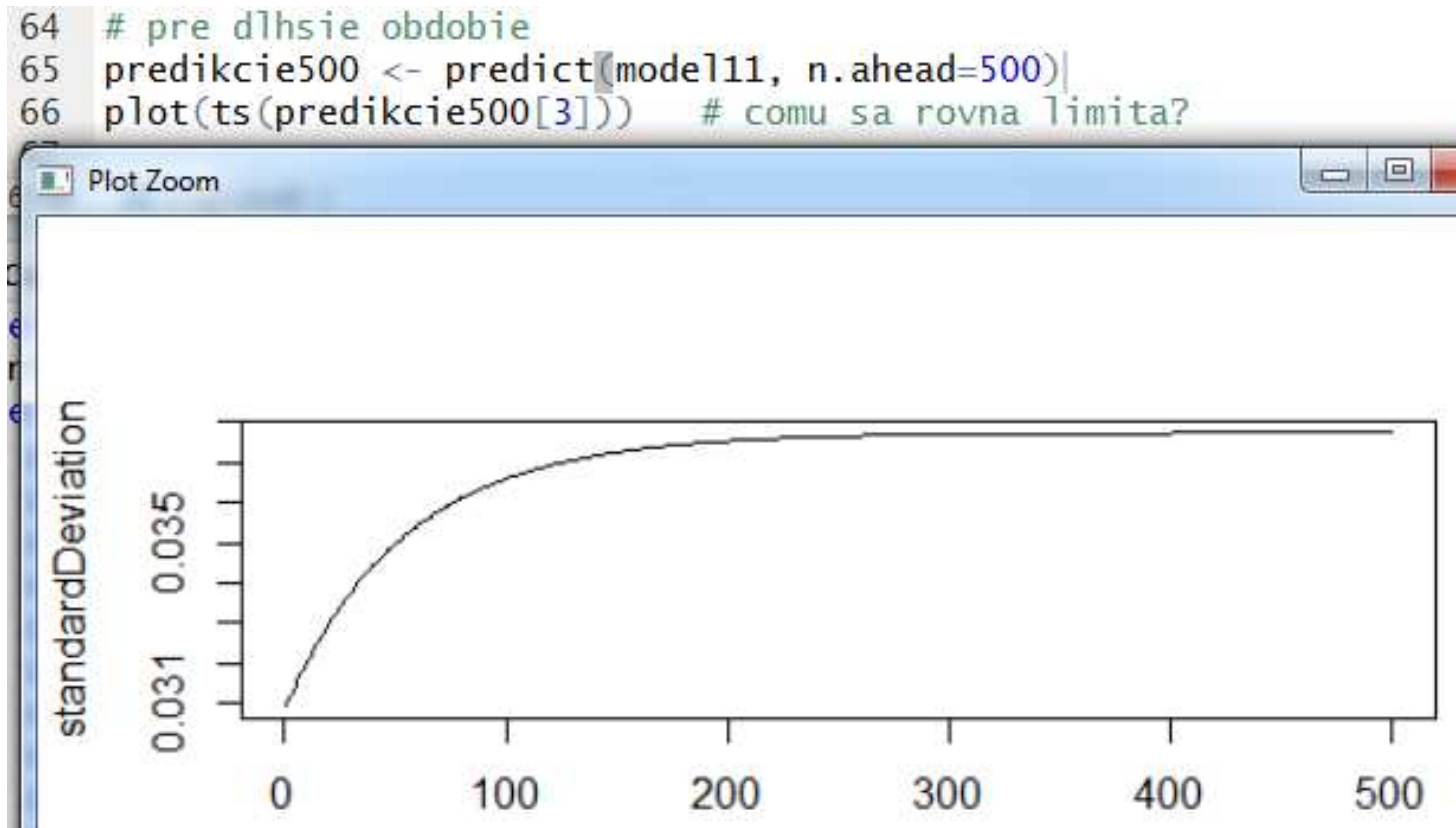
Predikcie

- Predikovaný vývoj štandardnej odchýlky:



Predikcie

- Predikovaný vývoj štandardnej odchýlky pre dlhšie obdobie - čomu sa rovná limita?



Aplikácia: Value at risk (VaR)

- Value at risk (VaR) je vlastne kvantil
- Nech X je hodnota portfólia; potom

$$\mathcal{P}(X \leq VaR) = \alpha,$$

napr. pre $\alpha = 0.05$

- Štandardne GARCH predpokladá normálne rozdelenie (dajú sa odhadovať aj iné rozdelenia) - vieme počítat kvantily
- Nedostatky:
 - ◇ predpoklad normality
 - ◇ sú aj lepšie miery rizika ako VaR

Aplikácia: Value at risk (VaR)

- NA CVIČENÍ:
 - ◇ Začneme po N hodnotách výnosov
 - ◇ Odhadneme GARCH model.
 - ◇ Spravíme predikciu pre štandardnú odchýlku a pomocou nej zostrojíme VaR pre výnos na nasledujúci týždeň
 - ◇ Každý týždeň posunieme okno s dátami (máme nové pozorovanie) odhadneme znovu GARCH a vypočítame nové VaR

Nepovinné - pre záujemcov

- <https://systematicinvestor.wordpress.com/2012/01/06/trading-using-garch-volatility-forecast/>
- *"... Now, let's create a strategy that switches between mean-reversion and trend-following strategies based on GARCH(1,1) volatility forecast."* + kódy v R-ku
- Obrázok zo stránky:



Iné modely pre volatilitu

- **Threshold GARCH:**
 - ◇ $u_t > 0$ - "good news", $u_t < 0$ - "bad news"
 - ◇ TARARCH umožňuje, aby mali na volatilitu rôzny vplyv
 - ◇ *leverage effect*: väčší vplyv na volatilitu majú *bad news*
- Nemodelujeme disperziu (ako v ARCH/GARCH modeloch), ale
 - ◇ jej logaritmus → **exponential GARCH**
 - ◇ ľubovoľnú mocninu štandardnej odchýlky → **power GARCH**
- a ďalšie...